

**MOŽNOSTI ZPŘESŇOVÁNÍ PREDIKCE
KONCENTRACÍ ZNEČIŠŤUJÍCÍCH LÁTEK
V OVZDUŠÍ POMOCÍ NEURONOVÝCH SÍTÍ
POSSIBILITIES OF NEURAL NETWORK BASED
AIR POLLUTANT CONCENTRATION PREDICTION
IMPROVEMENT**

Obsah

1 Úvod	2
2 Atmosféra	4
3 Látky znečišťující ovzduší	6
3.1 Legislativní nástroje pro ochranu ovzduší	9
4 Vybrané metody vhodné pro predikci koncentrací ZL v ovzduší	12
5 Umělé neuronové sítě	16
5.1 Model umělého neuronu	19
5.2 Vícevrstvá perceptronová síť (MLP)	22
5.3 Back – propagation algoritmus	23
5.4 Kohonenovy mapy	24
6 Zpřesňování predikcí PM₁₀	26
6.1 Predikce se zahrnutím více minulých měření	27
6.2 Predikce s nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	29
6.3 Predikcese zahrnutím koncentrací naměřených v okolních stanicích imisního monitoringu	32
6.4 Predikce s klasifikací charakteristických situací pomocí Kohonenových map	34
6.5 Další zpřesňování predikcí	37
6.6 Vyhodnocení a diskuze výsledků	40
7 Závěr	45
8 Použitá literatura	47
9 Seznam obrázků	51
10 Seznam tabulek	53
11 Seznam použitých zkratk	54

1 Úvod

Znečištěné ovzduší je důsledkem lidské činnosti, a to na základě vypouštění znečišťujících látek z různých zdrojů do ovzduší. Škodlivé látky ovlivňují nejen ovzduší v těsné blízkosti zdroje, ale také se jejich negativní účinky projevují i ve vzdálenějších oblastech, což je důsledek transportu částic v atmosféře. V 90. letech došlo k výraznému zlepšení kvality ovzduší v České republice, ale od počátku třetího tisíciletí se situace začala opět zhoršovat v souvislosti s rozvojem průmyslu a nárůstem dopravy.

Největší problém na našem území představují vysoké koncentrace prachových částic. Nejzávažnější situace je v Moravskoslezském kraji, především v oblasti Ostravsko-karvinské aglomerace, dále v Praze, Brně a severozápadních Čechách. V těchto oblastech dochází nejen k překračování dlouhodobých limitů koncentrací látek znečišťujících ovzduší, ale rovněž zde dochází ke smogovým situacím, které se projevují zvýšeným výskytem onemocnění a úmrtnosti. Mezi hlavní příčiny špatné kvality ovzduší patří zejména průmysl, hustá silniční doprava a rovněž i vytápění domácností nekvalitními tuhými palivy v zastaralých topných zařízeních [1],[2].

Při překročení prahových hodnot látek znečišťujících ovzduší je podle současné platné legislativy vyhlášen signál smogové regulace pro postižené území, kde podle smogového regulačního plánu je umožněna regulace zdrojů znečišťování ovzduší [3]. Jedná se zejména o omezení provozu významných průmyslových zdrojů a regulace dopravy, především pak vjezd automobilů do oblastí se zhoršenou kvalitou ovzduší.

Veškerá opatření ke snížení znečištění ovzduší mohou být uskutečněna až v okamžiku, kdy je výskyt smogu zaznamenán imisními monitorovacími stanicemi. Tedy jakákoliv přijatá opatření mohou smogovou situaci jen zmírnit nikoliv však předcházet jejímu vzniku. K ukončení smogové situace dochází až při zlepšení rozptylových podmínek pro znečišťující látky. Zefektivnění systému regulace smogových situací by bylo možné za předpokladu, že regulační opatření by byla účinná již v době převládání špatných rozptylových podmínek, jež by bez regulace vedly ke vzniku smogu. To ovšem souvisí se schopností předpovídat koncentrace znečišťujících látek.

Hlavním cílem diplomové práce je navázat na výsledky diplomové práce Markéty Dřezové, tedy najít a aplikovat vhodné metody, které by vedly ke zpřesnění predikcí koncentrací znečišťujících látek.

2 Atmosféra

Zemská atmosféra tvoří plynný obal Země, také označovaný jako ovzduší. Atmosféra se skládá z jednotlivých plynných složek, jejichž obsah není stálý díky neustále se měnícímu ovzduší. Kromě plynných složek obsahuje atmosférický vzduch i kapalně a tuhé složky ve formě aerosolů, které jsou tvořeny mikroskopickými částicemi hmoty, tuhými a kapalnými složkami rozptýlenými v plynném prostředí. Kapalně složky jsou v ovzduší přítomny ve formě mlhy a mraků tvořených drobnými kapičkami vody, které zkondenzovaly z vodní páry [4]. Hlavními složkami atmosféry jsou kyslík, dusík, oxid uhličitý a vzácné plyny. Dusík je v atmosféře zastoupen přibližně 78 %, kyslík 21 % a oxid uhličitý 0,03 %, ale jeho množství je proměnlivé. Dále se zde nacházejí v pevném i kapalném skupenství mikroorganismy, půdní částice, pylová zrna, kosmický prach, krystaly solí, produkty vulkanické činnosti apod. Převážně tyto částice slouží jako kondenzační jádra pro tvorbu dešťových kapek.

Zemská atmosféra představuje ochrannou vrstvu před negativními vlivy kosmického prostoru a zároveň absorbuje kosmické záření dopadající na její vnější vrstvy. Dále také pohlcuje Sluneční záření elektromagnetické povahy a propouští pouze radiaci a rádiové vlny. Atmosféra rovněž zajišťuje stabilizaci teploty přízemních vrstev ovzduší a zabraňuje tak teplotním výkyvům. Je bohatým zdrojem kyslíku, který je nezbytný k dýchání, zdrojem dusíku, jež využívají bakterie a zdrojem oxidu uhličitého tvořící základ pro fotosyntetické pochody. Zemská atmosféra je součástí hydrologického cyklu, kdy umožňuje transport vypařující se vody z oceánů nad zemský povrch [6].

Mezi základní charakteristiky ovzduší patří teplota, tepelná bilance atmosféry a tlakové poměry v atmosféře, nezbytně nutné k rozptylu znečišťujících látek v ovzduší. Fyzikální vlastnosti atmosféry jsou značně proměnné a závisí na nadmořské výšce, ročním období, zeměpisné poloze i sluneční aktivitě. Pokles tlaku má lineární charakter, zatímco pokles teploty je různý v jednotlivých vrstvách atmosféry.

Atmosféru lze dělit podle různých kritérií, nejdůležitější členění atmosféry je podle charakteru teplotních změn na následující vrstvy: troposféru (do 8 až 15 km), stratosféru (do 50 až 55 km), mezosféru (do 80 až 90 km), termosféru (do 400 km) a exosféru (nad 400 km), která ve výšce okolo 70 000 km přechází do volného vesmíru. Jednotlivé vrstvy jsou od sebe odděleny přechodovými mezivrstvami, jejichž tloušťka se pohybuje okolo 1-2 km. Nejdůležitější vrstva pro život na Zemi je troposféra, která tvoří 90 % hmotnosti atmosféry a

obsahuje veškerou vodu v atmosféře. Nad rovníkem dosahuje výšky okolo 17 km, nad póly pouze do výšky okolo 9 km. Typický pro troposféru je pokles teploty o $6,5^{\circ}\text{C}$ na 1 km výšky a pokles tlaku s výškou. Všechny povětrnostní jevy jako povětrnostní fronty, srážky a proudění vzduchu jsou omezeny právě na tuto vrstvu. Troposféru lze dělit na planetární hraniční vrstvu a volnou troposféru. Nad troposférou se nachází přechodová vrstva tropopauza, která je velmi chladná a slouží jako ochranná bariéra proti úniku vody do vyšších atmosférických hladin. Nad tropopauzou se rozkládá stratosféra, jejíž součástí je ozonoféra. Ozonoféra má vysoký obsah ozónu absorbující ultrafialové záření ze Slunce, čímž dochází k ohřevu této vrstvy. Mezoféra, navazující na asi 10 km silnou stratopauzu, se nachází ve výškách mezi 50 až 80 km a charakteristický je pro ni ostrý pokles teploty s výškou. V horních vrstvách mezoféry (okolo 80 km) se teplota pohybuje v rozmezí od -80°C do -100°C . Následuje 2 km silná mezopauza, na níž navazuje termosféra, kde teplota zpočátku této hladiny prudce s výškou roste, ve výškách okolo 500 – 700 km dosahují zředěné plyny teploty až 1200°C . Exosféra je poslední vrstvou atmosféry. Teplotní rozdíly zde nejsou příliš velké a postupně tato vrstva přechází volně v meziplanetární prostor [4],[5].

3 Látky znečišťující ovzduší

V oblasti ochrany ovzduší se setkáváme se dvěma základními pojmy - znečišťování a znečištění ovzduší. Pojem znečišťování ovzduší se používá pro vnášení neboli vypouštění (emisi) látek znečišťujících ovzduší do atmosféry. Jedná se tedy o činnost nebo děj. Přítomnost neboli obsah (imisi) těchto látek v ovzduší v takové době a míře trvání, při nichž se projeví nepříznivé ovlivňování životního prostředí, lze chápat jako znečištění ovzduší a jedná se tedy o určitý stav, který je důsledkem původního děje. Důvodem znečišťování ovzduší jsou emise ZL vypouštěných do ovzduší ze zdrojů znečišťování. Ovzduším jsou pak znečišťující látky transportovány od zdrojů k příjemcům. Znečišťující látky, vyskytující se v přízemní vrstvě atmosféry a nepříznivě působící na zdraví lidí, přírodu a hmotné statky, jsou označovány jako imise. Depozicemi pak rozumíme imise, jež se usadí nebo zachytí na zemském povrchu. Pojmem transmise je označován transport látek ovzduším.

Mezi emise přírodního původu řadíme řadu procesů jako sopečnou činnost, lesní a stepní požáry, přirozený rozklad organické hmoty, který představuje běžnou součást všech ekosystémů. Antropogenní emise jako důsledek lidské činnosti zahrnují emise vznikající při spalování organické hmoty, z průmyslových činností, spalování fosilních paliv, dopravy, zemědělství atd. [4],[5].


Za látky znečišťující ovzduší považujeme látky vnesené do vnějšího ovzduší nebo v něm druhotně vznikající, které buď přímo nebo po fyzikální či chemické přeměně v atmosféře, nebo po spolupůsobení s jinými látkami mají škodlivý vliv na prostředí. Při hodnocení znečišťování ovzduší je důležitým kritériem právě druh znečišťující látky. ZL se nejčastěji dělí podle skupenství na látky tuhé, kapalné a plynné. Dále podle chemického složení na sloučeniny síry, dusíku, kyslíku, uhlíku, halogenové sloučeniny a ostatní znečišťující látky. Podle účinku míry škodlivosti například podle jejich zdravotního účinku je lze dělit na skupiny zahrnující alergen, látky radioaktivní, karcinogenní, mutagenní, těžké kovy apod.

Oxidy síry. Nejvýznamnějším oxidem síry je oxid siřičitý SO_2 . Přírodním zdrojem tohoto oxidu je především vulkanická činnost. Hlavními antropogenními zdroji jsou elektrárny a teplárny, spalující paliva s vysokým obsahem síry, domácí topeniště a některé technologické procesy. Jedná se o bezbarvý dráždivý plyn, který negativně působí na zdraví živočichů, zejména pak na lidské zdraví, kdy poškozuje především dýchací systém. Může

akutně způsobit i kontrakci hladkých svalů dýchacího ústrojí, hlavně u astmatiků. Při vyšších koncentracích může způsobit snížení průchodnosti v plicích a dráždí oči a horní dýchací cesty. Oxid siřičitý je toxický i pro rostlinstvo, kdy může vyvolat viditelné příznaky poškození nebo snížení výnosu některých plodin, ale také k odumírání keřů a stromů.

Oxidy dusíku jsou v atmosféře zastoupeny v různých formách. Z hlediska negativního vlivu na životní prostředí je nejvýznamnější přítomnost oxidu dusnatého NO a dusičitého NO₂, které jsou označovány souhrnně jako NO_x. Mezi přírodní zdroje NO_x se řadí především činnost bakterií, vulkanická činnost a elektrické výboje v atmosféře, avšak velká část NO_x pochází ze spalovacích procesů probíhajících při výrobě energie, z dopravy a případně i z chemické výroby. Oxidy dusíku působí nepříznivě zejména na dýchací orgány, což může vést k jejich onemocnění, popřípadě i ke vzniku nádorových onemocnění. Při zvýšené koncentraci oxidu dusíku dochází k jeho vázání na hemoglobin a tím se zhoršuje přenos kyslíku z plic do krevního oběhu.

Kvalita ovzduší v České republice je do jisté míry ovlivněna také přítomností částic PM₁₀ a benzo(a)pyrenem. **Částice PM₁₀** představují riziko především z důvodu usazování v dýchacích cestách, kterým jsou lidé vystaveni při vdechování znečištěného ovzduší. Vliv prachových a aerosolových částic na lidské zdraví závisí zejména na jejich velikosti. Hlavním zdrojem suspendovaných částic jsou spalovací procesy, zejména v automobilových motorech a dalších technologické procesy. Částice PM₁₀ mohou vznikat v ovzduší sekundárními chemickými a fyzikálními reakcemi, například nukleací a kondenzací, dále resuspenzí nebo vlivem meteorologických faktorů. Při vdechování dochází k jejich usazování v dýchacích cestách. Částice menší než 10 μm se mohou usazovat v průduškách a způsobovat tak zdravotní problémy. Největší riziko představují částice menší než 1 μm, které mohou být vdechovány až do plicních sklípků. Suspendované částice většinou obsahují i karcinogenní sloučeniny. Krátkodobá expozice prachových částic má nepříznivé účinky na kardiovaskulární systém a také způsobuje zánětlivá onemocnění plic. Dlouhodobá expozice snižuje funkci plic u dětí i dospělých, způsobuje růst onemocnění dolních cest dýchacích, ale také snižuje délku dožití [4],[5].



Obrázek 1 Tvar pevných částic

(Zdroj: [8])

Benzo(a)pyren, u něhož byly prokázány karcinogenní účinky, patří do skupiny polycyklických aromatických uhlovodíků. Při vypouštění benzo(a)pyrenu do ovzduší dochází k jeho kumulaci nejen v životním prostředí, ale také v živých organismech, u nichž může negativně působit na plodnost mužů, porodní váhu novorozenců ale také ovlivnit růst plodu. Benzo(a)pyren má kromě karcinogenních také mutagenní a toxické vlastnosti. Benzo(a)pyren je obvykle navázán na částice PM_{10} a může vyvolat astma, bronchitidu, laryngitidu, záněty dutin a středního ucha, ekzémy a alergie.

V ovzduší jsou ZL vystaveny působení fyzikálních vlivů a chemickým změnám, čímž dochází ke vzniku sekundárního znečištění ovzduší, jež může mít podstatně nebezpečnější vlastnosti než znečištění primární. Znečištění tohoto typu označujeme jako tzv. **smog** a pochází ze spojení anglických slov smoke (kouř) a fog (mlha). Jedná se o stav mimořádně znečištěného ovzduší, kdy je atmosféra obohacena o složky, které v ní nejsou běžně přítomny. Smog lze dělit na dva typy:

- Redukční smog tzv. londýnský, jež vzniká spojením městského a průmyslového kouře s mlhou, se vyskytuje především během zimních období s přízemními inverzemi teploty vzduchu. Složení redukčního smogu závisí především na průmyslovém znečištění, převážně je tvořen oxidem siřičitým a látkami podléhajícími snadno oxidaci.

- Oxidační smog tzv. fotochemický neboli též losangeleský má silné oxidační, agresivní, toxické a dráždivé účinky. Oxidační smog je převážně tvořen ozonem a peroxidy organických látek vznikajících fotochemickými reakcemi v ovzduší. Má negativní dopad nejen na lidské zdraví, ale také na vegetaci a to především na zemědělské plodiny. Ozon, který je součástí tohoto druhu smogu, narušuje funkci buněk, což vede k poškození listů a jehličnanů a životně důležitých pochodů. Vyvolává pálení očí, dýchací potíže, malátnost nebo snižuje obranyschopnost organismu [4].

3.1 Legislativní nástroje pro ochranu ovzduší

Látky znečišťující ovzduší řeší ***zákon č. 86/2002 Sb., o ochraně ovzduší, ve znění pozdějších předpisů***, kde podle **§2** jsou vymezeny základní pojmy. Pro působnost zákona v oblasti ochrany ovzduší jsou definovány tyto vybrané pojmy:

- a) Znečišťující látka je jakákoliv látka vnesená do vnějšího ovzduší nebo v něm druhotně vznikající, která má přímo anebo může mít po fyzikální nebo chemické přeměně nebo po spolupůsobení s jinou látkou škodlivý vliv na život a zdraví lidí a zvířat, na životní prostředí, na klimatický systém Země nebo na hmotný majetek.
- b) Emisní limit je nejvýše přípustné množství znečišťující látky nebo stanovené skupiny znečišťujících látek nebo pachových látek vypouštěné do ovzduší ze zdroje znečišťování ovzduší vyjádřené jako hmotnostní koncentrace znečišťující látky v odpadních plynech nebo hmotnostní tok znečišťující látky za jednotku času nebo hmotnost znečišťující látky vztažená na jednotku produkce nebo lidské činnosti nebo jako počet pachových jednotek na jednotku objemu nebo jako počet částic znečišťující látky na jednotku objemu.
- c) Emisní strop je nejvýše přípustná úhrnná emise znečišťující látky nebo stanovené skupiny znečišťujících látek vznikající v důsledku lidské činnosti vyjádřená v hmotnostních jednotkách za období 1 roku ze všech zdrojů znečišťování ovzduší, z jejich vymezené skupiny nebo z jednotlivého zdroje znečišťování ovzduší na vymezeném území.
- d) Imisní limit je hodnota nejvýše přípustné úrovně znečištění ovzduší vyjádřená v jednotkách hmotnosti na jednotku objemu při normální teplotě a tlaku.

§8 tohoto zákona je zaměřen na problematiku smogových situací:

1. Smogová situace je stav mimořádně znečištěného ovzduší, kdy úroveň znečištění ovzduší znečišťující látkou překročí zvláštní imisní limit stanovený prováděcím právním předpisem.
2. Zvláštním imisním limitem podle odstavce 1 se rozumí taková úroveň znečištění ovzduší, při jejímž překročení hrozí již při krátké expozici riziko poškození lidského zdraví nebo poškození ekosystému.
3. Možnost vzniku, vznik a ukončení smogové situace vyhláší v rámci ústředního regulačního řádu ministerstvo nebo jím zřízená právnická osoba neprodleně. Současně se vznikem smogové situace vyhlásí regulační opatření k omezování emisí ze stacionárních zdrojů, které se na znečišťování ovzduší rozhodujícím způsobem podílejí.
4. Kraj a obec jsou povinny v oblastech se zhoršenou kvalitou ovzduší svým nařízením vydat regulační řád pro jejich území. V tomto regulačním řádu upraví vyhlásování a odvolávání signálu upozornění a signálu regulace na svém území v případě možnosti vzniku nebo výskytu smogové situace a omezení nebo zastavení provozu stacionárních a mobilních zdrojů znečišťování ve své územní působnosti, s výjimkou stacionárních zdrojů regulovaných podle odstavce 3. Při vypracování krajského a místního regulačního řádu krajský úřad a obecní úřad přihlédne k negativním důsledkům omezení nebo zastavení zemědělských provozů s chovem hospodářských zvířat.
5. Krajský regulační řád nesmí být v rozporu s ústředním regulačním řádem. Místní regulační řád nesmí být v rozporu s krajským regulačním řádem a s ústředním regulačním řádem.
6. Pro případ vzniku smogové situace může orgán ochrany ovzduší
 - a) nařídit provozovatelům stacionárních zdrojů omezení nebo zastavení provozu zdroje,
 - b) nařídit provozovatelům mobilních zdrojů znečišťování omezení provozu těchto zdrojů nebo zákaz tyto zdroje používat.
7. Regulační opatření lze vyhlásit na nezbytně nutnou dobu jen s uvedením důvodu a území, na které se regulační opatření vztahuje. V regulačním opatření orgán ochrany ovzduší uvede, na které osoby se regulační opatření vztahuje a jaká opatření jsou povinny strpět [7].

Regulační signál a signál smogové situace se vyhláší v době výrazného zhoršení kvality ovzduší. V případě, že tato situace nastala, jsou provozovatelé významných

průmyslových a energetických zdrojů povinni regulovat své zdroje podle schváleného regulačního řádu. Za účelem minimalizovat množství vypouštěných škodlivých látek do ovzduší se tyto varovné signály týkají do jisté míry i občanů a řidičů. Signály upozornění, regulace a varování jsou předmětem vyhlášky č. 373/2009 Sb. [3].

Zvláštní imisní limity se vyhláší pro oxid siřičitý, oxid dusičitý, suspendované částice PM_{10} a troposférický ozón. Hodnoty zvláštních imisních limitů uvádí příloha č. 1 vyhlášky č. 373/2009 Sb.

Signál upozornění následuje po překročení hodinového průměru koncentrace oxidu siřičitého $250 \mu\text{g.m}^{-3}$ nebo oxidu dusičitého $200 \mu\text{g.m}^{-3}$ anebo troposférického ozonu $180 \mu\text{g.m}^{-3}$ ve třech po sobě následujících hodinách. Nebo v případě překročení 24 hodinového průměru koncentrace suspendovaných částic PM_{10} $100 \mu\text{g.m}^{-3}$.

Signál regulace následuje po překročení hodinového průměru koncentrace oxidu siřičitého $500 \mu\text{g.m}^{-3}$ nebo oxidu dusičitého $400 \mu\text{g.m}^{-3}$ ve třech po sobě následujících hodinách. Nebo v případě překročení 24 hodinového průměru koncentrace suspendovaných částic PM_{10} $150 \mu\text{g.m}^{-3}$.

Signál varování se vyhláší po překročení hodinového průměru koncentrace troposférického ozonu $240 \mu\text{g.m}^{-3}$ ve třech po sobě následujících hodinách [3].

Problémem je především skutečnost, že signály regulace jsou spouštěny až v okamžiku, kdy již smogová situace nastala. Důsledkem je proto pouze snížení závažnosti situace, ale nikoli předcházení smogu.

Z tohoto důvodu by bylo vhodné mít nástroj, který by umožňoval předpověď koncentrací znečišťujících látek dopředu, a tak by se současně lidé mohli na tento zhoršený stav ovzduší připravit.

4 Vybrané metody vhodné pro predikci koncentrací ZL v ovzduší

Existuje celá řada modelů, sloužících k predikci znečišťujících látek v ovzduší, jako neuronové sítě, analýza časových řad, matematické modelování a statistická regrese. Tato práce navazuje na diplomovou práci Markéty Dřezové [25], kde autorka zvolila tvorbu predikčních modelů na základě neuronových sítí, jež dávají společně s analýzou časových řad docela kvalitní předpovědi, ale z důvodu matematické náročnosti byly zvoleny k predikci právě neuronové sítě, typu vícevrstvá perceptronová síť a RBF síť. V rámci řešení jsme se snažili objevit nějaké vhodné postupy, které by dále zpřesnily výsledky diplomové práce Markéty Dřezové, které se podařilo dosáhnout těchto výsledků:

Tabulka 1 Vyhodnocení statistických parametrů pro MLP síť podle Markéty Dřezové [25]

Pro PM ₁₀	MLP
Korelační koeficient	0,79
Střední kvadratická chyba [μg.m ⁻³]	14,92
Průměrná relativní chyba [%]	34

Z cca 50 prostudovaných článků, ve kterých je popisována tvorba předpovědního modelu pomocí neuronových sítí, bylo vybráno několik z nich, kde autoři využili některé metody, jež by mohly vést ke zlepšení výsledků predikčních modelů.

Ve Finsku v letech 1995 – 1997 skupina vědců okolo Mikko Kolehmainena zkoumala možnosti předpovídání koncentrací znečišťujících látek v oblasti města Kuopio. K předpovědi využili vlastní typ neuronové sítě - samoorganizující mapy se Sammonovým mapováním (SOM), pro které se později vžil název Kohonenovy mapy. Vstupními údaji pro predikci byli rychlost větru, směr větru, teplota a hodinové koncentrace NO, NO₂, CO a PM₁₀. SOM jsou neuronové sítě „bez učitele“ a jejich výsledkem je kategorizace stavů kvality ovzduší do charakteristických situací. Výsledky byly vyhodnoceny pomocí statistických ukazatelů, odchylkou střední kvadratické hodnoty (RMSE) a indexem shody. Z tabulky je patrné, že přesnost modelu byla vyšší pro plyny než pro pevné částice [9].

Tabulka 2 Statistické parametry pro SOM použité ve Finsku [9]

Proměnná	RMSE	Index shody d
NO ₂ [µg.m ⁻³]	12,2	0,66
CO [mg.m ⁻³]	0,3	0,63
PM ₁₀ [µg.m ⁻³]	11,1	0,47

Ve Švédsku během let 1994 – 1998 skupina vědců vedena Mikko Kolehmainenem zkoumala možnosti zlepšení kvality ovzduší. Vstupní data byly hodnoty poskytnuté 4 měřicími stanicemi ve Stockholmu. Dalšími vstupními daty jsou meteorologické data – teplota, směr větru, rychlost větru, sluneční záření, hodina dne a měsíc v roce. K předpovědi koncentrace NO₂ využili dva postupy:

1. postup za použití neuronové sítě – opakuje se i dále
2. postup, kdy využili známé vlastnosti o periodických složkách dat, kdy data rozdělili na periodickou a neperiodickou část. Neperiodickou část pak testovali pomocí NN.

Testováním periodické složky dat pomocí MLP se jim podařilo dosáhnout indexu shody 0.89 a odchylky střední kvadratické hodnoty 11.41 µg.m⁻³ [10].

Ve Španělsku v tříletém období 1999-2001 skupina vědců okolo Francisca J. Gonzáleze se snažila rozvíjet modely pro predikci úrovně znečištění ovzduší v různých městech po celém regionu Campo de Gibraltar. Pro předpovídání koncentrací CO, SO₂ a suspendovaných částic (SPM), měřených v µg.m⁻³, bylo provedeno srovnání 4 různých postupů – NN, model ARIMA, který patří do kategorie statistické analýzy časových řad, vícerozměrnou lineární regresi (MLR), perzistentní model (PER), který je založený na předpovídání koncentrací 1 hodinu a 24 hodin dopředu. Na základě srovnání výsledků těchto 4 postupů vychází, že nejhorší výsledky má MLR, lepší výsledky model ARIMA a PER, kde nejlepších výsledků se podařilo dosáhnout pro koncentrace CO. Ze všech těchto modelů měly nejlepší výsledky umělé neuronové sítě (ANN), kterým se podařilo dosáhnout následujících výsledků [11]:

Tabulka 3 Výsledky předpovědního modelu použitého ve Španělsku [11]

Znečišťující látka	Předpověď n hodin dopředu	Index shody d
CO [$\mu\text{g.m}^{-3}$]	1	0,88
	24	0,76
SO ₂ [$\mu\text{g.m}^{-3}$]	1	0,80
	24	0,70
SPM [$\mu\text{g.m}^{-3}$]	1	0,69
	24	0,91

V Chorvatsku Lovro Hrust, Josip Križan, Oleg Antičić a další vědci zkoumali použitelnost vícevrstvé perceptronové sítě (MLP) pro predikci koncentrací CO, NO₂, PM₁₀ a O₃. K předpovědi užíli meteorologické parametry jako vlhkost, směr a rychlost větru, tlak vzduchu a teplotu. Celkové datové sady obsahovaly 15 - min měřené průměrné hodnoty znečišťujících látek. Z výsledků vyplynulo, že zásadní vliv pro předpovědi mají meteorologické parametry uvedené výše, ale složka větru byla nahrazena vektory proudění vzduchu.

Tabulka 4 Vyhodnocení statistických parametrů za použití MLP sítě testované v Chorvatsku [12]

	Parametr	NN model optim.
NO ₂	MAE [$\mu\text{g.m}^{-3}$]	5,34
	RMSE [$\mu\text{g.m}^{-3}$]	7,56
	IA	0,96
	R ²	0,87
O ₃	MAE [$\mu\text{g.m}^{-3}$]	8,26
	RMSE [$\mu\text{g.m}^{-3}$]	10,86
	IA	0,97
	R ²	0,90
CO	MAE [mg.m^{-3}]	0,16
	RMSE [mg.m^{-3}]	0,24
	IA	0,93
	R ²	0,77
PM ₁₀	MAE [$\mu\text{g.m}^{-3}$]	9,24
	RMSE [$\mu\text{g.m}^{-3}$]	13,26
	IA	0,91
	R ²	0,72

Parametry byly průměrovány, za účelem získat optimální hodnoty, které by nejlépe popisovali meteorologickou situaci [12].

V Turecku v letech 2005 - 2006 skupina vědců vedena Atakanem Kurtem se snažila předpovídat průměrné koncentrace znečišťujících látek SO₂, CO a PM₁₀ tři dny dopředu na

základě NN, konkrétně vícenásobné perceptronové sítě. Vstupními údaji jsou: relativní vlhkost, maximální denní teplota, minimální noční teplota, rychlost větru, směr větru a tlak se zahrnutím dne v týdnu. Z experimentů vyplynulo, že absolutní chyba je obecně vyšší pro SO₂ než u dalších dvou polutantů, jak je patrné z tabulky.

Tabulka 5 Vyhodnocení statistických parametrů za použití MLP sítě v Turecku [13]

Znečišťující látka	Absolutní chyba [%]	Relativní chyba [%]
SO ₂ [μg.m ⁻³]	50	20
PM ₁₀ [μg.m ⁻³]	30-40	10
CO [μg.m ⁻³]	35	10

Relativní chyba u SO₂ je vyšší, ale i přesto je stále přijatelná. Tento model je v současnosti využíván pro předpovídání smogových situací v Istanbulu [13].

Atakan Kurt a Ayşe Betül Oktay se snažili model vylepšit na základě údajů z okolních imisně-monitorovacích stanic. Byly provedeny tři různé experimenty:

- 1) byly použity hodnoty z nejbližší vedlejší stanice
- 2) hodnoty ze dvou nejbližších vedlejších stanic
- 3) model, který zahrnoval i vzdálenost měřících stanic od sledovaného místa

Z výsledků experimentů vyplynulo, že model, který zahrnuje i vzdálenost stanic, je schopný výrazně zlepšit výsledky původního modelu [14].

5 Umělé neuronové sítě


Umělé neuronové sítě jsou inspirovány neuronovými sítěmi biologického původu. Z tohoto důvodu lze očekávat, že umělé neuronové sítě by měly být schopny, z hlediska základních principů, se chovat stejně nebo alespoň podobně jako jejich biologické vzory. Vytvoření umělého lidského mozku se všemi jeho schopnostmi je velmi těžce realizovatelné ať už z hlediska velkého množství neuronů či jejich způsobu propojení, chování jednotlivých typů neuronů apod.

Neuronové sítě využívají distribuovaný výpočetní systém, který se skládá z dílčích podsystémů, tedy neuronů. Tento uměle vytvořený systém pracuje na základě síly vazeb mezi jednotlivými neurony [15].

Neuronové sítě pronikly do mnoha vědních oborů a mají široké možnosti uplatnění při řešení různých problémů, jako například zpracování řeči, detekce pravidelnosti, zpracování obrazu, ovládání robotů, predikce časových řad a další [16].

Nervová soustava člověka zprostředkovává vztahy mezi organismem a vnějším prostředím a zajišťuje tak odpovídající reakci na vnější podněty i na vnitřní stavy organismů. Uvedený proces probíhá prostřednictvím šíření signálů z jednotlivých čidel tzv. receptorů, které umožňují přijímat mechanické, tepelné, chemické a světelné podněty. Tyto signály se šíří směrem k jiným nervovým buňkám, jež přijaté signály zpracovávají a přivádí k dalším výkonným orgánům – efektorům [17].

Základní stavební jednotkou centrálního nervového systému je neuron, viz **Obrázek 2**. Neurony představují samostatné specializované buňky, které slouží k přenosu, zpracování a uchování informací nezbytných pro realizaci životních funkcí organismu. Neuronová síť představuje vzájemné propojení neuronů do síťové struktury. V neuronové síti je neuronová tkáň tvořena dendrity, jež jsou spojeny s tělem buňky. Axon, dlouhý výběžek buňky, který přenáší informace z těla neuronu do dalších buněk přes synaptická spojení, dendrity.



Obrázek 2 Biologický neuron

(Zdroj: <http://www.stockphotos.cz>)


Z pohledu zpracovávání a uchovávání informací lze neuron rozdělit na tyto tři základní části:

- *Synaptické spojení*. Představují místa přijímání vzruchů, tedy informací a také místa uchovávání znalostí od jiných neuronů.
- *Tělo buňky* (soma), které přijímá informace ze synaptických spojení a dále je zpracovává.
- *Axon*. Dlouhý výběžek přenášející výstupní signál v podobě zpracovaných informací k synapsím dalších neuronů.

Uvnitř těla přijímací buňky se realizuje efekt zvyšování či snižování elektrického potenciálu. Pokud potenciál dosáhne určité úrovně, dojde k aktivaci výstupního signálu do axonu, kde se signál rozvětví a po určité době dosáhne synaptického spojení jiných buněk [18].

Soubory neuronů a jejich vzájemné elektrochemické vazby vytvářejí složité sítě, které jsou vzorem pro matematické modely neuronových sítí v počítačích a při výzkumu umělé inteligence [19].

V roce 1943 Warren McCulloch a Walter Pittse navrhli jeden z prvních modelů neuronu a tento model je dodnes používán pro běžné aplikace. Vzájemným propojením těchto neuronů umožnili realizovat libovolnou reálnou funkci.



Obrázek 3 McCullochův – Pittsův neuron (perceptron)


(Zdroj: [18])

O šest let později přispěl k rozvoji neuronových sítí také D. Hebb, který navrhl učící pravidlo (tzv. Hebbovo pravidlo), kde váha spoje mezi dvěma neurony je nastavena pomocí velikostí aktivit obou neuronů. V roce 1957 navrhl F. Rosenblatt tzv. perceptron, jež představoval zobecnění McCullochova a Pittsova modelu neuronu (viz **Obrázek 3**) pro reálný obor parametrů. Rovněž našel pro tento perceptron učící pravidlo. T. Kohonen v letech 1982 rozšířil myšlenku kompetitivního učení a na základě těchto podkladů vynalezl tzv. Kohonenovu síť (Kohonenovy mapy). V tomto roce také J. Hopfield publikoval výsledky studia magnetických materiálů s využitím sítě, kde uvedl použití energetické funkce s využitím sítě a vybavování, a díky těmto poznatkům se síť stala známou jako Hopfieldova síť. V roce 1986 tři vědci D. Rumelhart, G. Hinton a R. Williams popsali učící algoritmus zpětného šíření umožňující učení vícevrstvé perceptronové sítě [19].

5.1 Model umělého neuronu

Uměle vytvořený neuron je dán svým biologickým vzorem a tvoří základní výpočetní jednotku složitějšího komplexu – neuronové sítě. Skládá se ze tří hlavních částí: vstupní, funkční a výstupní části. Vstupní část se skládá ze vstupů a z přiřazených, synaptických vah. Další částí je výkonná jednotka zpracovávající informace ze vstupu. Následuje vygenerování výstupní odezvy, která je přes výstupní jednotku v podobě informace přivedena na vstup jiných neuronů.

Paměť umělého neuronu není samostatnou jednotkou, ale je rozložena ve vstupní části ve formě váhových koeficientů, které realizují sílu odezvy na vzruch, kdy je schopen učit se adekvátně, tedy reagovat na podněty takovým způsobem, aby bylo dosaženo žádaného výsledku [16].



Obrázek 4 Umělý neuron

(Zdroj: [19])

Model neuronu (viz **Obrázek 4**) obsahuje řadu vstupů (x_1, x_2, \dots, x_n), které mají příslušné váhy spojů (w_1, w_2, \dots, w_n). Dále se zde nachází jeden formální vstup ($x_0 = 1$) a citlivost neboli bias ($w_0 = -\theta$). Vnitřní potenciál neuronu je dán hodnotou ξ a $y = f(\xi)$ představuje výstup neuronu získaný aplikací aktivační funkce na potenciál.

Matematicky lze neuron popsat dvěma operacemi:

1. Výpočet potenciálu neuronu ξ daný rovnicí (1)

$$\xi = \sum_{i=0}^n w_i \cdot x_i \quad (1)$$

2. aktivační nebo přechodová operace, popsána aktivační funkcí $y = f(\xi)$ daná rovnicí (2)

Mezi nejčastěji používané aktivační funkce ξ se řadí tzv. klasická sigmoidální funkce, tj. funkce ve tvaru „S“ křivky popsanou rovnicí (2) nebo hyperbolický tangens (3) [19].


$$f(\xi) = \frac{1}{1 + \exp(-\lambda \xi)} \quad (2)$$

kde ξ je vnitřní potenciál neuronu

λ je parametr strmosti


$$y = \tanh(\lambda \xi) \quad (3)$$

kde ξ je vnitřní potenciál neuronu



Obrázek 5 Sigmoida (logistická funkce) pro $\lambda=1$

(Zdroj: Autor)



Obrázek 6 Hyperbolický tangens pro $\lambda=1$

(Zdroj: Autor)

Podle topologie lze neuronové sítě rozdělit do dvou hlavních skupin:

- na sítě s dopředným šířením signálu, tzv. dopředné neuronové sítě
- na sítě se zpětnou vazbou, tzv. rekurentní neuronové sítě [21]

Významnou vlastností neuronových sítí je učení, čímž se rozumí účelová adaptace synaptických vah a to tak, aby neuronová síť měla na výstupu požadovanou odezvu. Tedy aby vzniklá chyba, daná rozdílem mezi požadovanou hodnotou a odezvou sítě, byla co nejmenší. Z tohoto důvodu se technika neuronových sítí, v porovnání s jinými analytickými a modelovacími technikami, spojuje s vlastností přijatelné chybové tolerance.

Způsob nastavení vah sítě ve fázi učení závisí na její konkrétní aplikaci. Učící algoritmy lze na základě způsobu adaptace synaptických vah rozdělit do dvou skupin:


- algoritmy využívající učení s předlohou, jsou založené na chybě
- algoritmy využívající učení bez předlohy, založené na výstupu

Učením neuronové sítě rozumíme proces optimalizování parametrů funkce. To znamená, že úlohou neuronové sítě je vyhledat funkci s takovými optimalizovanými parametry, aby odchylka mezi skutečným a požadovaným výstupem byla co nejmenší. Pro učení neuronové sítě je potřeba mít množinu reprezentativních příkladů, která je v praktické realizaci rozložena na dvě části – trénovací a testovací množinu. Trénovací množina slouží pro učení neuronové sítě, zatímco testovací množina slouží pro ověření kvality výsledků

neuronové síť. Fáze učení neuronové síť se označuje jako fáze adaptivní a může být i časově náročná. Po naučení síť následuje fáze vybavování, kde výpočet hodnoty v neuronové síti představuje dosazení do jednoduchého vzorce [18].

5.2 Vícevrstvá perceptronová síť (MLP)

Vrstevná síť (vícevrstvý perceptron, multi-layer perceptron) je nejznámější a nejrozšířenější typ neuronové síť, kde základní jednotku tvoří neuron zvaný perceptron. Řadí se mezi síť s učitelem, tzn., že trénovací vzory musí znát vstupní a výstupní dvojici hodnot [15].



Obrázek 7 Vícevrstvá perceptronová síť

(Zdroj: [15])

Vícevrstvou perceptronovou síť, znázorněnou na **Obrázku 7**, tvoří minimálně tři vrstvy neuronů: vstupní a výstupní vrstva a minimálně jedna vrstva vnitřní. Sousední vrstvy neuronů jsou propojeny tak, že dochází k tzv. úplnému propojení neuronů. Každý neuron nižší vrstvy je spojen se všemi neurony vrstvy vyšší. Počet vrstev i počet neuronů v jednotlivých vrstvách představují parametry sítě a závisí na konkrétní úloze.

Tento typ neuronové sítě pracuje s reálnými hodnotami, což znamená, že výstupy, stavy, váhy i potenciály jsou všeobecně reálnými čísly. Vhodným nastavením vah se zajišťuje správná činnost sítě. Způsob nastavení vah je předmětem učení sítě, které využívá vybavovací fázi a z toho důvodu nejdříve probíhá fáze vybavování a až poté fáze učení.

Vícevrstvá perceptronová síť se řadí mezi sítě využívající při učení gradientní metodu a z tohoto důvodu může dojít při pohybu po chybové funkci k uváznutí sítě v lokálním minimu. Mezi nejdůležitější metody odstraňující problém uváznutí sítě v lokálním minimu patří:

- *Velikost parametru učení.* Může významně ovlivnit rychlost učení a konvergenci k řešení.
- *Moment.* Po přidání do rovnice pro adaptaci vah představuje nejrozšířenější způsob ochrany před uváznutím sítě v lokálním minimu.
- *Šum.* Přidáním šumu do rovnice pro adaptaci vah lze narušit pohyb po chybové funkci ve směru gradientu.
- *Přidání neuronů.* Pokud se síť učí vzory, jež jsou si velmi podobné, potom budou jejich odpovídající minima na chybové funkci blízko sebe. Vlastnosti sítě mohou být zhoršeny při malém počtu neuronů, kdy minima nebudou dostatečně reprezentována a dokonce mohou splynout. Přidáním jednoho nebo více neuronů do skryté vrstvy můžeme dosáhnout zjemnění chybové funkce [19].

5. 3 Back – propagation algoritmus


Back – propagation představuje algoritmus zpětného šíření neboli sítě se zpětným šířením chyby. Je klasickým algoritmem pro učení vícevrstvé neuronové sítě a jeho učení probíhá s předlohou ve dvou fázích. V první fázi se jedná o šíření vstupních signálů na výstupy sítě a výpočet chyby v poslední vrstvě. Druhá fáze zahrnuje zpětné šíření chyby do jednotlivých neuronů v nižších vrstvách s následnou modifikací vah [18]. Tento algoritmus pracuje tak, že opravuje, popř. nastavuje váhy jednotlivých spojů takovým způsobem, aby jejich velikosti z pohledu řešeného problému byly co nejoptimálnější – hledá se globální minimum chybové funkce. Nastavení vah probíhá v opačném směru než šíření vstupní informace. Algoritmus tedy hledá globální minimum chybové funkce a snaží se, aby se globální chyba přiblížila co nejvíce globálnímu minimu chybové funkce [20].

Back-propagation algoritmus má i řadu nevýhod. Zejména, že chybová funkce závisí na všech vahách a díky tomu se jedná o funkce velice komplexní, tedy má mnoho lokálních minim. Algoritmus založený na gradientní metodě vede vždy do nejbližšího minima, které nemusí být globální.

Dalším problémem je také množství učicích parametrů, jež nejsou algoritmem určeny, ale závisí na nich úspěšná konvergence chybové funkce. Optimální nastavení těchto parametrů může významně ovlivnit úspěšnost učení [22],[23].

5. 4 Kohonenovy mapy

Samoorganizující mapy (SOM) nebo také Kohonenovy mapy, jejichž zakladatelem je finský vědec Teuvo Kohonen (1982), se v současné době řadí k nejvíce užívaným typům neuronových sítí založených na principech kompetitivního učení. Jedná se o jednovrstvou neuronovou síť patřící do skupiny sítí s učením bez učitele, která umožňuje vizualizovat topografii a hierarchickou strukturu multidimenzionálních dat transformací do prostoru nižší dimenze, tedy tzv. kompresi dat. Na zobrazení skrytých informací v multidimenzionálních datech se nejčastěji používá dvourozměrné mapy (dvojdimenzionální zobrazení).



Obrázek 8 Topologie SOM

(Zdroj: [18])

V SOM se zpravidla rozlišují tři prostory, jak je patrné z **Obrázku 11**. Prostor vstupních dat, prostor neuronů, který je zpravidla topologicky uspořádaný jako mřížka nebo řetěz, a prostor váhových vektorů. Jednotlivé přímky spojující body sousedních neuronů představují prostorové váhy mezi neurony v prostoru vah.

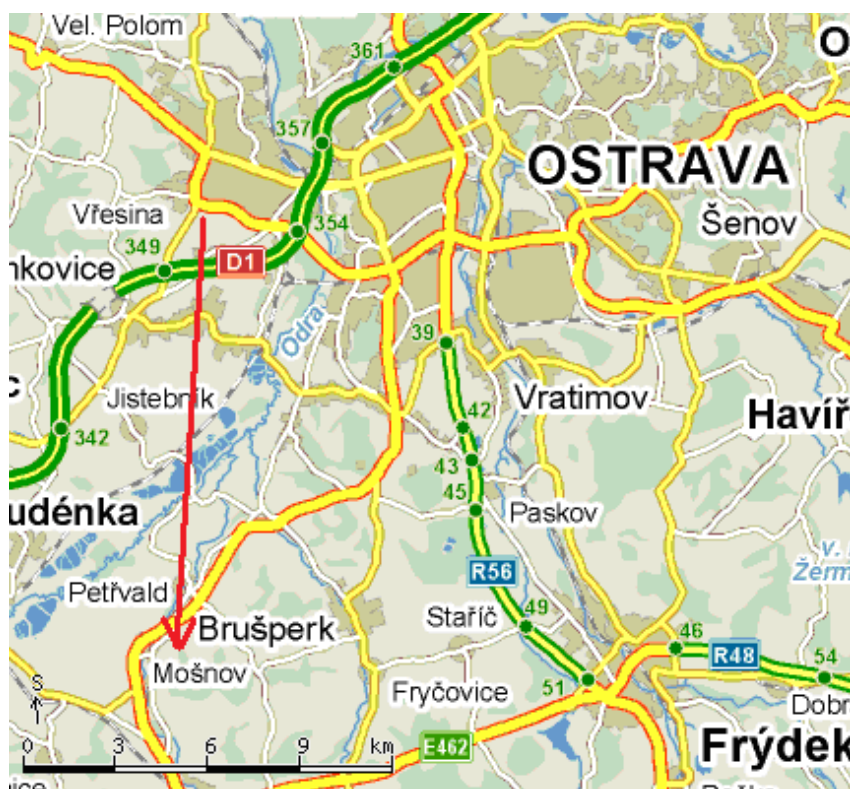
Grafickým výstupem SOM je topologická mapa, jako je např. Sammonova mapa, jež v dvojdimenzionální vizualizaci představuje původně Euklidovy vzdálenosti mezi vzory vstupních vektorů.

Technika analýzy dat pomocí Kohonenovy samoorganizující sítě je často alternativní aplikací k mnohým jiným velmi složitým metodám analýzy dat používaných v různých oblastech, jako např. v kvantové mechanice, v analýze a predikci ekonomických a finančních veličin apod. [18].

6 Zpřesňování predikcí PM_{10}

Úkolem testování neuronových sítí bylo především navázat na výsledky diplomové práce Markéty Dřezové [26] a najít nějaký vhodný způsob, který by vedl ke zpřesnění predikcí ZL v ovzduší a následně předpověď pomocí vybraných modelů realizovat ve vybrané lokalitě. Konkrétními testovanými neuronovými sítěmi budou vícevrstvá perceptronová síť (MLP) a Kohonenovy mapy. Vybranou lokalitou byla zvolena stanice imisního monitoringu Ostrava – Poruba. Neuronové sítě byly testovány pro znečišťující látku PM_{10} , kde její denní průměrná koncentrace se stanovuje gravimetricky [24].

Stanice imisního monitoringu se nachází v areálu pobočky Českého hydrometeorologického ústavu (ČHMÚ). Stanice byla zvolena z důvodu, že ve stejné lokalitě jsou dostupné i výsledky meteorologických měření. Tato data nejsou ovšem veřejně přístupná, pouze za finanční úhradu. Proto nebyla z finančních důvodů použita a místo nich byla použita data z meteorologické stanice Mošnov, jež jsou volně dostupná. Veškerá použitá data byla naměřena v letech 2005 – 2009.



Obrázek 9 Meteorologická stanice v Mošnově


(Zdroj: www.mapy.cz)

Pro testování neuronových sítí byl použit software STATISTICA, ve kterém se testování provádí velice efektivně. K předpovědi byla vybrána znečišťující látka PM_{10} . Tato ZL byla predikována pomocí čtyř vybraných modelů, kde jako vstupní parametry byly použity hodnoty koncentrací PM_{10} z aktuálního dne a meteorologické parametry z následujícího dne, především minimální a maximální denní teplota, tlak, rychlost a směr větru. Z čtyřletého období let 2005 – 2009 bylo k dispozici 1414 zaznamenaných údajů, obsahující úplná vstupní i cílová data. Pro účely výpočtů byla sada záznamů rozdělena na trénovací množinu (80 % záznamů) a testovací množinu (20 %). Bylo vyzkoušeno přibližně 1000 různých konfigurací, kde ze všech zkoušených konfigurací neuronových sítí byla za nejvhodnější zvolena taková konfigurace, která měla nejnížší hodnotu střední kvadratické chyby předpovědi pro testovací sadu dat.

6.1 Predikce se zahrnutím více minulých měření

Znečišťující látka PM_{10} se zkoušela nejprve předpovídat pomocí modelu vícevrstvé perceptronové sítě (MLP) s jednou skrytou vrstvou, ve které minimální počet neuronů byl 3 a maximální počet neuronů 20. Aktivační funkce použité v modelu pro testování byli hyperbolický tangens a sinoida. Nejlepších výsledků pro konfiguraci dosahovala síť MLP 12-6-1, kde 12 charakterizuje počet neuronů ve skryté vrstvě a 1 značí jeden výstupní neuron. Vstupními parametry použitými pro tuto síť byli hodnoty koncentrací PM_{10} naměřených 7 dní zpátky, minimální a maximální denní teplota, rychlost a směr větru, tlak.

Úspěšnost predikce je na následujícím grafu.




Obrázek 10 Srovnání naměřených a predikovaných koncentrací PM_{10} pomocí vícevrstvé perceptronové sítě

Ze závislosti rozptýlu naměřených koncentrací PM_{10} k predikovaným koncentracím PM_{10} je patrné, že u nejčastěji dosahovaných hodnot koncentrací ($10 - 40 \mu\text{g.m}^{-3}$) model dobře předpovídá naměřené hodnoty. U vyšších koncentrací (nad $80 \mu\text{g.m}^{-3}$) se vyskytují odlehle hodnoty, odkud tedy vyplývá, že předpovědi jsou nepřesné a model má tendenci výsledky podhodnocovat. S velkou pravděpodobností má na predikci vliv i jiný parametr, který nebyl postihnout.

Statistické vyhodnocení předpovědi koncentrace PM_{10} pomocí tohoto modelu je uvedeno v **Tabulce 6**.

Tabulka 6 Statistické vyhodnocení predikce PM_{10} se zahrnutím více minulých měření jako vstupů pro model


Pro PM_{10}	MLP
Korelační koeficient	0,83
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	13,77
Průměrná relativní chyba [%]	32



Obrázek 11 Histogram rozložení rozdílů predikce a naměřených hodnot


6.2 Predikce s nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu

Znečišťující látka PM_{10} se dále zkoušela předpovídat pomocí modelu vícevrstvé perceptronové sítě (MLP) s jednou skrytou vrstvou, ve které minimální počet neuronů byl 3 a maximální počet neuronů 20. Aktivační funkce použité v modelu pro testování byli hyperbolický tangens a sigmoida. Nejlepších výsledků pro konfiguraci dosahovala síť MLP 7-17-1, kde 17 charakterizuje počet neuronů ve skryté vrstvě a 1 značí jeden výstupní neuron. Aktivační funkce použitá k testování byla sigmoida. Použitými vstupy pro model byli minimální a maximální denní teplota, tlak, hodnoty koncentrací PM_{10} z předchozího dne, rychlost větru a složka větru nahrazená vektory proudění vzduchu.



Obrázek 12 Nahrazení úhlu a rychlosti větru složkami vektoru proudění vzduchu

Úspěšnost predikce je na následujícím grafu.



Obrázek 13 Srovnání naměřených a predikovaných koncentrací PM_{10} pomocí vícevrstvé perceptronové sítě


Ze závislosti rozptýlu naměřených koncentrací PM_{10} k predikovaným koncentracím PM_{10} je patrné, že u nejčastěji dosahovaných hodnot koncentrací ($10 - 40 \mu g.m^{-3}$) model

dobře předpovídá naměřené hodnoty. U vyšších koncentrací (nad $80 \mu\text{g.m}^{-3}$) se vyskytují odlehle hodnoty, odkud tedy vyplývá, že předpovědi jsou nepřesné a model má tendenci výsledky podhodnocovat. S velkou pravděpodobností má na predikci vliv i jiný parametr, který nebyl postihnut.

Statistické vyhodnocení předpovědi koncentrace PM_{10} pomocí tohoto modelu je uvedeno v **Tabulce 7**.

Tabulka 7 Statistické vyhodnocení predikce PM_{10} pomocí MLP nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu


Pro PM_{10}	MLP
Korelační koeficient	0,83
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	13,84
Průměrná relativní chyba [%]	33



Obrázek 14 Histogram rozložení rozdílů predikce a naměřených hodnot

6.3 Predikce se zahrnutím koncentrací naměřených v okolních stanicích imisního monitoringu

Dalším testovaným modelem pro předpověď koncentrace PM_{10} byl model vícevrstvé perceptronové sítě zahrnující i jako vstupní parametr koncentrace naměřené na okolních stanicích imisního monitoringu. Vícevrstvá perceptronová síť měla opět jednu skrytou vrstvu, kde minimální počet neuronů byl 3 a maximální počet neuronů 20. Aktivační funkce použité pro testování byly rovněž hyperbolický tangens a sigmoida. Nejlepších výsledků ze všech možných konfigurací dosahovala síť MLP 10-8-1, která se vyznačovala právě nejmenší střední kvadratickou chybou. Číslo 8 značí počet neuronů ve skryté vrstvě a 1 představuje jeden výstupní neuron, jenž prezentuje právě hodnotu denních koncentrací PM_{10} . Aktivační funkce pro tuto konfiguraci byla funkce hyperbolický tangens. K predikci bylo použito celkem 6 vstupních parametrů – minimální a maximální denní teplota, tlak, směr větru, rychlost větru a hodnoty koncentrací PM_{10} z předchozího dne naměřených na okolních stanicích imisního monitoringu – Fifejdy, Studénka, Zábřeh. Úspěšnost predikce je na následujícím grafu.




Obrázek 15 Srovnání naměřených a predikovaných koncentrací PM₁₀ pomocí vícevrstvé perceptronové sítě

Z grafické závislosti rozptylu naměřených koncentrací PM₁₀ k predikovaným koncentracím PM₁₀ je zřejmé, že predikované hodnoty v oblasti nízkých koncentrací (10-40 µg.m⁻³) dobře předpovídají naměřené hodnoty, ale v oblasti vyšších koncentrací (nad 80 µg.m⁻³) se nacházejí odlehlé hodnoty. Předpovědi jsou tedy nepřesné a model má tendenci výsledky podhodnocovat. Je pravděpodobné, že na predikci má vliv i jiný parametr, který nebyl postihnut.

Statistické parametry pro tento model uvádí **Tabulka 8**.

Tabulka 8 Statistické vyhodnocení predikce PM₁₀ se zahrnutím koncentrací naměřených na okolních stanicích imisního monitoringu

Pro PM ₁₀	MLP
Korelační koeficient	0,84
Střední kvadratická chyba [µg.m ⁻³]	13,53
Průměrná relativní chyba [%]	32



Obrázek 16 Histogram rozložení rozdílů predikce a naměřených hodnot


6.4 Predikce s klasifikací charakteristických situací pomocí Kohonenových map

Kohonenovy mapy řadíme do skupiny sítí s učením bez učitele, což znamená, že k učení této sítě postačuje velká skupina reálných dat, které mají buď něco společného, nebo naopak odlišného. Zda data mají společné znaky nebo naopak se nějakým způsobem liší, umí tato síť rozpoznat sama.

Model je tedy založen na rozdělení jednotlivých stavů počasí do charakteristických skupin tzv. pozic, přičemž výsledkem je topologická mapa s topologickou výškou 6 a topologickou šířkou 6. Použitými vstupy pro tento model byly minimální a maximální denní teplota, rychlost a směr větru, tlak a hodnoty koncentrací PM_{10} z předchozího dne.

Na základě rozdělení jednotlivých stavů počasí do charakteristických pozic byla následně využita vícevrstvá perceptronová síť s jednou skrytou vrstvou pro každou situaci, kde minimální počet neuronů byl 3 a maximální počet neuronů 20. Aktivační funkce použité

pro tento model byli hyperbolický tangens a sigmoida. Na následujícím grafu je znázorněna úspěšnost predikce.




Obrázek 17 Srovnání naměřených a predikovaných koncentrací PM₁₀ za použití SOM+MLP

Ze závislosti rozptylu naměřených koncentrací PM₁₀ k predikovaným koncentracím PM₁₀ je patrné, že predikované hodnoty v oblasti nízkých koncentrací (10-40 µg.m⁻³) dobře předpovídají naměřené hodnoty. V případě vyšších koncentrací (nad 80 µg.m⁻³) se objevují v grafu i odlehlé hodnoty a predikce je tedy nepřesná. Model má tendenci hodnoty podhodnocovat a v některých případech odhadovat predikované hodnoty jako konstanty, kdy se jedná o takové situace počasí, kdy při stejných vstupních datech můžou koncentrace PM₁₀ výrazně stoupnout i klesnout. Bližším rozbořem takových situací (viz. **Příloha 1**) bylo zjištěno, že hodnoty koncentrací jsou v těchto situacích patrně výrazně ovlivněny srážkami.

Statistické parametry pro tento model uvádí **Tabulka 9**.

Tabulka 9 Statistické vyhodnocení predikce PM_{10} za použití MLP+SOM

Pro PM_{10}	SOM+MLP
Korelační koeficient	0,88
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	12,21
Průměrná relativní chyba [%]	26



Obrázek 18 Histogram rozložení rozdílů predikce a naměřených hodnot

V případě tohoto modelu se nám podařilo střední kvadratickou chybu výrazně snížit v porovnání s předchozími třemi modely, a proto jsme se rozhodli tento model vylepšit přidáním dalších vstupních parametrů.


6.5 Další zpřesňování predikcí

6.5.1 Predikce s klasifikací charakteristických situací pomocí Kohonenových map a s nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu

Nejprve jsme využili Kohonenovy mapy k rozdělení jednotlivých stavů počasí do charakteristických skupin (pozic), kde použitými vstupními parametry byli minimální a maximální denní teplota, tlak, hodnoty koncentrací PM_{10} z předchozího dne, rychlost větru a složka větru nahrazená vektory proudění vzduchu. Výstupem byla topologická mapa s topologickou výškou 6 a šířkou 6.

Poté jsme využili pro jednotlivé pozice vícevrstvou perceptronovou síť s jednou skrytou vrstvou, kde minimální počet neuronů byl 3 a maximální počet neuronů 15. Aktivační funkce použitá pro tento model byla hyperbolický tangens a sigmoida.

Ze závislosti rozptylu naměřených koncentrací PM_{10} k predikovaným koncentracím PM_{10} vyplývá, že v oblasti nižších koncentrací ($10-40 \mu g.m^{-3}$) predikované hodnoty dobře popisují hodnoty naměřené. U vyšších koncentrací (nad $80 \mu g.m^{-3}$) se vyskytují i odlehle hodnoty, ale je patrné, že v porovnání s předchozím grafem došlo k výraznému snížení předpovídaných konstantních hodnot.




Obrázek 19 Srovnání naměřených a predikovaných koncentrací PM₁₀ za použití SOM+MLP nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu

Statistické vyhodnocení parametrů pro tento model je uvedeno v **Tabulce 10** a podrobnější statistika výsledků pro tento model je uvedena v **Příloze 2**.

Tabulka 10 Statistické vyhodnocení predikce PM₁₀ nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu

Pro PM ₁₀	
Korelační koeficient	0,87
Střední kvadratická chyba [μg.m ⁻³]	11,02
Průměrná relativní chyba [%]	25




Obrázek 20 Histogram rozložení rozdílů predikce a naměřených hodnot

6.5.2 Rozšíření vstupních údajů o parametry sněžení a deště

Za použití Kohonenových map byly rozděleny jednotlivé stavy počasí do charakteristických skupin (pozic). Výstupem pak byla topologická mapa s topologickou výškou 6 a topologickou šířkou 6. Vstupy pro síť tvořili následující parametry: minimální a maximální denní teplota, tlak, rychlost větru, směr větru, hodnoty koncentrací PM_{10} z předchozího dne a parametry sněh, dešť. V případě, že v daný den pršelo nebo sněžilo, pak byla v síti těmito situacím přiřazena 1, naopak pokud se v daný den nevyskytovaly žádné srážky, byla v síti těmito situacím přiřazena 0. Na základě údajů získaných z Kohonenových map byla pro každou situaci použita MLP síť s jednou skrytou vrstvou, kde minimální počet neuronů byl 3 a maximální počet neuronů 15. Aktivačními funkcemi byli opět hyperbolický tangens a sigmoida.

Úspěšnost predikce je na následujícím grafu.



Obrázek 21 Srovnání naměřených a predikovaných koncentrací PM_{10} za použití SOM+MLP přidáním vstupních parametrů sněžení a deště


Ze závislosti rozptylu naměřených a predikovaných koncentrací PM_{10} je patrné, že v případě nižších koncentrací ($10\text{--}40 \mu\text{g.m}^{-3}$) model dobře předpovídá naměřené hodnoty. V oblasti vyšších koncentrací (nad $80 \mu\text{g.m}^{-3}$) se vyskytují i odlehle hodnoty, ale v porovnání

s grafem na **Obrázku 16** došlo k výraznému zlepšení, kdy predikované hodnoty mnohem více odpovídají naměřeným hodnotám. Model nemá tendenci předpovídat konstantní hodnoty.

Statistické parametry jsou uvedeny v **Tabulce 11**, podrobnější statistika výsledků je uvedena v **Příloze 3**.

Tabulka 11 Statistické parametry predikce PM_{10} se zahrnutím parametrů sněžení a déšť

Pro PM_{10}	
Korelační koeficient	0,91
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	9,94
Průměrná relativní chyba [%]	25



Obrázek 22 Histogram rozložení rozdílů predikce a naměřených hodnot

6.6 Vyhodnocení a diskuze výsledků

V této práci byly vyzkoušeny celkem 4 modely (viz. Uvedeno výše) využívající k testování neuronové sítě. Konkrétně byly použity vícevrstvá perceptronová síť s různými


vstupními parametry a samoorganizující mapy, zvané též Kohonenovy mapy, umožňující kategorizaci stavů počasí do charakteristických skupin. V porovnání s výsledky Markéty Dřezové, jak je patrné z **Tabulky 12**, bylo zjištěno, že došlo k nepatrnému zlepšení. Největší zpřesnění přinesly Kohonenovy mapy.

Tabulka 12 Souhrnné vyhodnocení statistických parametrů predikce PM₁₀


Predikce PM ₁₀ pomocí MLP sítě podle Markéty Dřezové	
Korelační koeficient	0,79
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	14,92
Průměrná relativní chyba [%]	34
Predikce PM ₁₀ pomocí MLP sítě se zahrnutím více minulých měření	
Korelační koeficient	0,83
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	13,77
Průměrná relativní chyba [%]	32
Predikce PM ₁₀ pomocí MLP sítě nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	
Korelační koeficient	0,83
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	13,84
Průměrná relativní chyba [%]	33
Predikce PM ₁₀ pomocí MLP sítě zahrnutím koncentrací naměřených v okolních stanicích imisního monitoringu	
Korelační koeficient	0,84
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	13,54
Průměrná relativní chyba [%]	32
Predikce PM ₁₀ pomocí SOM a MLP sítí	
Korelační koeficient	0,88
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	12,21
Průměrná relativní chyba [%]	26
Predikce PM ₁₀ pomocí SOM a MLP sítí pro každou situaci nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	
Korelační koeficient	0,87
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	11,02
Průměrná relativní chyba [%]	25
Predikce PM ₁₀ pomocí SOM a MLP sítí pro každou situaci přidáním parametrů sněh, déšť	
Korelační koeficient	0,91
Střední kvadratická chyba [$\mu\text{g.m}^{-3}$]	9,94
Průměrná relativní chyba [%]	25

Když se použili další vstupní parametry jako možnost zpřesnění modelu kombinujícího Kohonenovy mapy a vícevrstvou perceptronovou síť, podařilo se dosáhnout ještě lepších výsledků. Střední kvadratická chyba činila v případě zahrnutí vstupního parametru sněžení a déšť $9,94 \mu\text{g.m}^{-3}$ a u modelu, kde byla složka větru nahrazena vektory proudění vzduchu $11,02 \mu\text{g.m}^{-3}$, což je téměř o 1/3 nižší než v porovnání s výsledky Markéty Dřezové, které se podařilo dosáhnout střední kvadratické chyby $14,92 \mu\text{g.m}^{-3}$.

Úspěšnost predikce podle výsledků Markéty Dřezové je na následujícím grafu (viz. **Obrázek 23**).



Obrázek 23 Predikce PM10 pomocí MLP podle Markéty Dřezové



Obrázek 24 Histogram rozložení rozdílů predikce a naměřených hodnot v porovnání s výsledky Markéty Dřezové

Meteorologická stanice v Mošnově se nachází přibližně 12 km vzdušnou čarou od stanice imisního monitoringu Ostrava-Poruba. Navíc jsou meteorologická měření v této lokalitě silně ovlivněna morfologií terénu – Moravskou branou, která výrazně ovlivňuje směr a rychlost větru, především z jižních, jihozápadních a západních směrů. Z tohoto důvodu nemusí naměřené meteorologické ukazatele být vždy reprezentativní i pro lokalitu imisní monitorovací stanice. Použitím meteorologických dat z této stanice by šlo pravděpodobně výsledky predikcí ještě více zpřesnit. Tato meteorologická data existují, ale bylo by je nutné pořídit od ČHMÚ za finanční poplatek v řádu desítek tisíc.

7 Závěr

Cílem diplomové práce bylo navázat na výsledky diplomové práce Markéty Dřezové, tedy najít a aplikovat vhodné metody, které by vedly ke zpřesnění predikcí koncentrací znečišťujících látek. Tyto metody pak aplikovat na reálná data z vybrané lokality Ostrava - Poruba. Hodnoty koncentrací znečišťující látky PM_{10} byly převzaty ze stanice imisního monitoringu nacházejícího se v areálu pobočky Českého hydrometeorologického ústavu, data meteorologická pak byla získána z meteorologické stanice v Mošnově.

Predikce koncentrací znečišťující látky PM_{10} byla uskutečněna pomocí neuronových sítí za použití software STATISTICA. Neuronové sítě byly zvoleny především z důvodu jejich nenáročnosti na vstupní data, poměrně jednoduché tvorby předpovědních modelů, časově nenáročného vytváření předpovědí, vyšší přesnosti predikcí v porovnání s jinými metodami a také možnosti přidání dalších vstupních parametrů do předpovědního modelu. Konkrétními neuronovými sítěmi použitými v této práci byly vícevrstvá perceptronová síť (MLP) a Kohonenovy mapy (SOM).

Byly testovány celkem 4 modely se zahrnutím různých vstupních parametrů. První model zahrnoval i jako vstupní parametr více minulých měření, kde se podařilo dosáhnout střední kvadratické chyby $13,77 \mu g.m^{-3}$. Dále byly hodnoty koncentrací PM_{10} predikovány pomocí modelu, kde úhel a rychlost větru byly nahrazeny složkami vektoru proudění vzduchu. Tento postup odstraňuje nedostatek popisu směru větru pomocí úhlu, kdy hodnotou velmi odlišné úhly 359° a 1° jsou ve skutečnosti prakticky totožným směrem větru. Model přinesl jen nepatrné zlepšení výsledků. Střední kvadratická chyba v tomto případě činila $13,84 \mu g.m^{-3}$. Dalším modelem použitým pro předpověď koncentrací PM_{10} byla vícevrstvá perceptronová síť zahrnující mimo jiné i hodnoty koncentrací PM_{10} z předchozího dne, naměřených na okolních stanicích imisního monitoringu - Fifejdy, Studénka, Zábřeh. I tento model přinesl nepatrné zlepšení, střední kvadratická chyba činila $13,53 \mu g.m^{-3}$. Nejlepších výsledků se podařilo dosáhnout testováním modelu, který umožňoval rozdělení stavů počasí do charakteristických situací pomocí Kohonenových map. Tyto jednotlivé situace pak byly modelovány každá zvlášť pomocí vícevrstvé perceptronové sítě. Střední kvadratická chyba byla nižší v porovnání s předchozími modely a to $12,21 \mu g.m^{-3}$.

Protože Kohonenovy mapy přinesly nejvýraznější zlepšení, byly vyzkoušeny a otestovány další možnosti, jak výsledky ještě více zpřesnit. Byly provedeny dva

experimenty, kdy v prvním modelu byl nahrazen úhel a rychlost větru složkami vektoru proudění vzduchu a v druhém modelu byly navíc zahrnuty další vstupní parametry sněžení a déšť. Výsledky se podařilo zlepšit téměř o 1/3 v porovnání s výsledky Markéty Dřezové. Střední kvadratická chyba v případě modelu, kde úhel a rychlost větru byly nahrazeny složkami vektoru proudění, činila $11,02 \mu\text{g.m}^{-3}$. U modelu zahrnujícího vstupní parametry sněžení a déšť činila střední kvadratická chyba $9,94 \mu\text{g.m}^{-3}$.

Meteorologická stanice v Mošnově se nachází přibližně 12 km vzdušnou čarou od stanice imisního monitoringu Ostrava-Poruba. Navíc jsou meteorologická měření v této lokalitě silně ovlivněna morfologií terénu – Moravskou branou, která výrazně ovlivňuje směr a rychlost větru, především z jižních, jihozápadních a západních směrů. Z tohoto důvodu nemusí naměřené meteorologické ukazatele být vždy reprezentativní i pro lokalitu imisní monitorovací stanice. Použitím meteorologických dat z této stanice by šlo pravděpodobně výsledky predikcí ještě více zpřesnit. Tato meteorologická data existují, ale bylo by je nutné pořídit od ČHMÚ za finanční poplatek v řádu desítek tisíc.

8 Použitá literatura

- [1] Stav ovzduší v ČR. *Mojeklima.cz* [online]. 2010 [cit. 2012-02-06]. Dostupné z WWW: <http://www.mojeklima.cz/index.php?route=cms/article&path=3&article_id=8>
- [2] Ovzduší v ČR znečišťuje topení uhlím a automobilová doprava. *Gnosis9.net* [online]. 14. 11. 2007 [cit. 2012-02-06]. Dostupné z WWW: <<http://gnosis9.net/view.php?cislocclanku=2007110012>>
- [3] *Vyhláška č. 373/2009 Sb., kterou se stanoví hodnoty zvláštních imisních limitů znečišťujících látek, ústřední regulační řád a způsob jeho provozování včetně seznamu stacionárních zdrojů podléhajících regulaci, zásady pro vypracování a provozování krajských a místních regulačních řádů a způsob a rozsah zpřístupňování informací o úrovni znečištění ovzduší veřejnosti* [online]. Praha: Ministerstvo životního prostředí [cit.2012-02-06]. Dostupný na WWW: <<http://www.mzp.cz/www/platnalegislativa.nsf/d79c09c54250df0dc1256e8900296e32/0790ed72b7188594c12576ef00359c0d?OpenDocument>>
- [4] Obroučka, Karel. *Ochrana ovzduší I*. Ostrava: Vysoká škola podnikání, a.s. v Ostravě, 2003. 81 s. ISBN: 80-86764-00-1
- [5] Obroučka, Karel. *Látky znečišťující ovzduší*. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava, 2001. 73 s. ISBN: 80-248-0011
- [6] Herčík, Miloslav. *Životní prostředí. Základy environmentalistiky*. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava, 2006. 142 s. ISBN: 80-248-1073-5
- [7] *Zákon č. 86/2002 Sb., o ochraně ovzduší* [online]. Praha: Ministerstvo životního prostředí [cit. 2012-02-06]. Dostupný na WWW: <<http://www.mzp.cz/www/platnalegislativa.nsf/d79c09c54250df0dc1256e8900296e32/ed2986242760af40c125754b003bb44a?OpenDocument>>
- [8] <<http://www2.brno.cz/download/kbzm/2007GB08.pdf>>

- [9] KOLEHMAINEN, Mikko. Forecasting Air Quality Parameters Using Hybrid Neural Network Modelling. *Environmental Monitoring and Assessment*. Kuopio, Finland, 2004, vol. 65 (numbers 1-2), 277-286. DOI: 10.1023/A:1006498914708. [cit. 2011-10-12] Dostupné z WWW:
<<http://www.springerlink.com/content/u7tg050873268102>>
- [10] KOLEHMAINEN, Mikko. Neural networks and periodic components used in air quality forecasting. *Atmospheric Environment*. 2001, vol. 35 (issue 5), 815-825. DOI: 10.1016. [2011-10-12] Dostupné z WWW:
<<http://www.sciencedirect.com/science/article/pii/S135223100000385X>>
- [11] TURIAS, Ignacio J. Prediction models of CO,SPM and SO₂ concentrations in the Campo de Gibraltar Region, Spain: a multiple comparison strategy. *Environmental monitoring and Assessment*. 2008, vol. 143, 131-146.
[cit. 2011-10-14] Dostupné z WWW:
<<http://www.springerlink.com/content/?k=Prediction+models+of+CO%2c+SPM+and>>
- [12] HRUST, Lovro. Neural network forecasting of air pollutants hourly concentrations using optimised temporal averages of meteorological variables and pollutant concentrations. *Atmospheric Environment*. 2009 (issue 35), 5588-5596. [cit. 2011-11-20] Dostupné z WWW:
<<http://www.sciencedirect.com/science/article/pii/S1352231009006669>>
- [13] KURT, Atakan. An online pollution forecasting system using neural network. *Environment International*. 2008, vol. 34(issue 5), 592-598.
[cit. 2011-11-22] Dostupné z WWW:
<<http://www.sciencedirect.com/science/article/pii/S0160412007002310>>
- [14] KURT, Atakan. Forecasting air pollutant indicator levels with geographic models 3 days in advance using neural networks. *Expert Systems with Applications*. 2010, vol. 37(issue 12), 7986-7992. [cit. 2011-11- 22]
Dostupné z WWW:
<<http://www.sciencedirect.com/science/article/pii/S095741741000504X>>

- [15] VONDRÁK, Ivo. *Umělá inteligence a neuronové sítě*. 2. vydání. Ostrava: VŠB-Technická univerzita Ostrava, 2002. 140 s. ISBN 80-7078-949-2
- [16] HORDĚJČUK, Ing. Vojtěch. *Voho.cz* [online].[cit. 2011-11-05]. Neuronové sítě. Dostupné z WWW: <<http://voho.cz/wiki/neuronove-site/>>
- [17] *Jlswbs.wordpress.com* [online].[cit. 2011-11-05]. Biologický neuron a neuronové sítě. Dostupné z WWW: <<http://jlswbs.wordpress.com/2009/07/09/biologicky-neuron-a-neuronove-site/>>
- [18] MARČEK, Dušan. *Neuronové sítě a Fuzzy časové řady*. Opava: Slezská univerzita v Opavě, 2002. 151 s. ISBN 80-7248-157-6
- [19] MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ, Jiří LAŽANSKÝ a kolektiv. *Umělá inteligence (4)*. 1. Praha: Akademie věd České republiky, 2003. 475 s. ISBN 80-200-1044-0.
- [20] MACHÁČ, Martin. *Toolbox pro neuronové sítě pro prostředí Mathematica* [online]. Zlín, 2009. 73 s. Diplomová práce. Univerzita Tomáše Bati ve Zlíně. Dostupné z WWW: <http://dspace.knihovna.utb.cz/bitstream/handle/10563/10979/mach%C3%A1%C4%8D_2009_dp.pdf?sequence=1>
- [21] MOLNÁR, Karol. Úvod do problematiky umělých neuronových sítí. *Elektrorevue* [online]. 22. 2. 2000, 13, [cit. 2011-11-16]. Dostupný z WWW: <<http://www.elektrorevue.cz/clanky/00013/index.html>>. ISSN 1213-1539
- [22] Neuronové sítě- výuka 2. In *Neuronové sítě 2* [online]. 2006 [cit. 2011-11-18]. Dostupné z WWW: <iss.unas.cz>
- [23] SVITÁK, Jiří. *Neuronové sítě a predikce časových řad* [online]. Brno, 2010 [cit. 2012-01-03]. Dostupné z WWW: <http://www.fit.vutbr.cz/study/DP/rpfile.php?id=10031>. Bakalářská práce. Vysoké učení technické v Brně.
- [24] Pobočka Ostrava- oddělení ochrany čistoty ovzduší [Online]. Portál ČHMÚ,

[cit. 2012-15-4]. Dostupné z WWW:

<http://portal.chmi.cz/portal/dt?menu=JSPTabContainer/P5_0_O_nas/P5_3

[_Organizacni_struktura/P5_3_18_Pobocka_OS/P5_3_18_1_Odd_meteo_kli](#)

[ma/P5_3_18_1_1_Zakl_Info&last=false](#)>

- [25] DŘEZOVÁ, Markéta. *Predikce koncentrací znečišťujících látek v ovzduší*. Ostrava, 5. 5. 2011. 57 s. Diplomová práce. VŠB-TU Ostrava. Vedoucí práce RNDr. Jan Bitta

9 Seznam obrázků

Obrázek 1 Tvar pevných částic	8
Obrázek 2 Biologický neuron	17
Obrázek 3 McCullochův – Pittsův neuron (perceptron)	18
Obrázek 4 Umělý neuron	19
Obrázek 5 Sigmoida (logistická funkce) pro $\lambda=1$	20
Obrázek 6 Hyperbolický tangens pro $\lambda=1$	21
Obrázek 7 Vícevrstvá perceptronová síť	22
Obrázek 8 Topologie SOM	24
Obrázek 9 Meteorologická stanice v Mošnově	26
Obrázek 10 Srovnání naměřených a predikovaných koncentrací PM10 pomocí vícevrstvé perceptronové sítě	28
Obrázek 11 Histogram rozložení rozdílů predikce a naměřených hodnot	29
Obrázek 12 Nahrazení úhlu a rychlosti větru složkami vektoru proudění vzduchu	30
Obrázek 13 Srovnání naměřených a predikovaných koncentrací PM10 pomocí vícevrstvé perceptronové sítě	30
Obrázek 14 Histogram rozložení rozdílů predikce a naměřených hodnot	32
Obrázek 15 Srovnání naměřených a predikovaných koncentrací PM10 pomocí vícevrstvé perceptronové sítě	33
Obrázek 16 Histogram rozložení rozdílů predikce a naměřených hodnot	34
Obrázek 17 Srovnání naměřených a predikovaných koncentrací PM10 za použití SOM+MLP	35
Obrázek 18 Histogram rozložení rozdílů predikce a naměřených hodnot	36

Obrázek 19 Srovnání naměřených a predikovaných koncentrací PM10 za použití SOM+MLP nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	38
Obrázek 20 Histogram rozložení rozdílů predikce a naměřených hodnot.....	38
Obrázek 21 Srovnání naměřených a predikovaných koncentrací PM10 za použití SOM+MLP přidáním vstupních parametrů sněžení a déšť	39
Obrázek 22 Histogram rozložení rozdílů predikce a naměřených hodnot.....	40
Obrázek 23 Predikce PM10 pomocí MLP podle Markéty Dřezové	43
Obrázek 24 Histogram rozložení rozdílů predikce a naměřených hodnot v porovnání s výsledky Markéty Dřezové.....	44

10 Seznam tabulek

Tabulka 1 Vyhodnocení statistických parametrů pro MLP síť podle Markéty Dřezové [25]	12
Tabulka 2 Statistické parametry pro SOM použité ve Finsku [9]	13
Tabulka 3 Výsledky předpovědního modelu použitého ve Španělsku [11]	14
Tabulka 4 Vyhodnocení statistických parametrů za použití MLP sítě testované v Chorvatsku [12]	14
Tabulka 5 Vyhodnocení statistických parametrů za použití MLP sítě v Turecku [13]	15
Tabulka 6 Statistické vyhodnocení predikce PM_{10} se zahrnutím více minulých měření jako vstupů pro model	28
Tabulka 7 Statistické vyhodnocení predikce PM_{10} pomocí MLP nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	31
Tabulka 8 Statistické vyhodnocení predikce PM_{10} se zahrnutím koncentrací naměřených na okolních stanicích imisního monitoringu	33
Tabulka 9 Statistické vyhodnocení predikce PM_{10} za použití MLP+SOM	36
Tabulka 10 Statistické vyhodnocení predikce PM_{10} nahrazením úhlu a rychlosti větru složkami vektoru proudění vzduchu	38
Tabulka 11 Statistické parametry predikce PM_{10} se zahrnutím parametrů sněžení a deště ..	40
Tabulka 12 Souhrnné vyhodnocení statistických parametrů predikce PM_{10}	42

11 Seznam použitých zkratek

ZL.....znečišťující látka

RMSE.....odchylka střední kvadratické chyby

(Root Mean Square Error)

MAE.....střední odchylka (Mean Absolute Error)

IA.....index shody (Index of Agreement)

R².....koeficient determinanosti

RBFneuronová síť využívající rádiové báze funkce

(Radial Basis Function)

MLP.....vícevrstvá perceptronová síť (Multilayer Perceptron)

SOM.....samoorganizující mapy (Self-organizing map)

ČHMÚ.....Český hydrometeorologický ústav